



RSC777-3

قضایا بحثیة 3

Task3

Prepared by

Mohammed Omar Bin Makhashen

242001540@st.midocean.edu.km

محمد عمر بن مخاشن

Ph.D. student in IT

2025-Feb-22

المحتوى

دراسة وتحليل احدى الدراسات الحديثة من حيث

- منهية المستخدمة
- النتائج المتوصل اليها

عنوان الرسالة: (Exploratory Quantum Machine Learning Techniques For Hybrid Systems)

اسم المؤلف: (Dominic Pasquali)

الجامعة: (UC Santa Cruz)

الدرجة العلمية: دكتوراه في الفلسفة (Doctor of Philosophy)

تاريخ تقديم الرسالة: ٢٠٢٣ ديسمبر

بشكل عام، هذه الرسالة تقدم مساهمة قيمة في مجال التعلم الآلي الكمومي. يستكشف الباحث مجموعة متنوعة من التقنيات الجديدة لدمج التعلم الآلي الكمومي في نماذج التعلم الآلي الأخرى. على الرغم من أن بعض هذه التقنيات لم تحقق تحسناً كبيراً في الأداء في المهام التي تم اختبارها عليها، إلا أن البعض الآخر أظهر نتائج واعدة. تشير النتائج إلى أن دمج الدوائر الكمومية مع المصفوفات أحادية الوحدة أو الشبكات العصبية المتصاعدة يمكن أن يؤدي إلى تحسين الأداء والكفاءة.

تحليل المنهجية: (يتبع)

- تطوير النموذج الهجين (Hybrid Model Development):

- دور المنهجية الأساسية حول إنشاء نماذج هجينة تدمج تقنيات الحوسبة الكلاسيكية والكمومية. يشمل ذلك:

- الانتباه الذاتي الكمومي (Quantum Self-Attention): استبدال الانتباه الذاتي الكلاسيكي في محاولات الرؤية (ViT) ببنية هجينة كلاسيكية-كمومية تستخدم دوائر كمومية تباينية مدربة.

- المصفوفات أحادية الوحدة (Unimodular Matrices): استخدام مصفوفات أحادية الوحدة ذات معاملات متغيرة داخل الدوائر الكمومية لتعلم الاقترانات والتحويلات في إطار هجين.

- شبكات عصبية سبايكنج متكاملة (Integrated Spiking Neural Networks): الجمع بين الشبكات العصبية سبايكنج (SNNs) وتعلم الآلة الكمومي للاستفادة من مزايا كليهما، مثل كفاءة الطاقة ومكاسب زمن الوصول (latency).

تحليل المنهجية: (يتبع)

- تقنيات المكونات (Component Technologies):

يعتمد النهج على العديد من تقنيات المكونات:

- **تعلم الآلة الكلاسيكي (Classical Machine Learning):** يستخدم مكونات كلاسيكية مثل الطبقات الخطية الكثيفة والطبقات الالتفافية.
- **الحوسبة الكمومية (Quantum Computing):** يستخدم الدوائر الكمومية، والدوائر الكمومية التباينية، والترميز الدوراني (دوران Ry)، وعمليات القياس.
- **الشبكات العصبية سبايكنج (Spiking Neural Networks):** يستخدم نماذج الخلايا العصبية المتسربة والتكاملية والإطلاق (LIF) والتدرجات البديلة لمحاكاة سلوك الخلايا العصبية وتمكين الانتشار العكسي.

تحليل المنهجية: (يتبع)

- التحسين والتدريب (Optimization and Training):

تشمل طرق التحسين والتدريب:

- الانتشار العكسي (Backpropagation): يستخدم لتحديث أوزان الشبكة العصبية بناءً على دالة الخسارة.
- نزول التدرج (Gradient Descent): يستخدم لتحسين المعلمات في المكونات الكلاسيكية والكمومية.
- دوال الخسارة (Loss Functions): يتم استخدام متوسط الخطأ المربع وخسارة معدل سبايكنج بالتقاطع الانتروبي لقياس الفرق بين المخرجات المتوقعة والمتوقعة.
- قاعدة إزاحة المعلمة (Parameter Shift Rule): يتم تطبيقها لحساب تدرجات البوابات الكمومية.
- طرق الفروق المحدودة (Finite Difference Methods): يتم استخدام طرق الفروق المحدودة الأمامية والخلفية والمركزية لتقريب التدرج.

تحليل المنهجية: (يتبع)

- التقييم الإحصائي (Statistical Evaluation):

يتم استخدام الطرق الإحصائية للتحقق من أداء النماذج المطورة:

- قياس أداء المعايير (Performance Benchmarking): يتم قياس أداء النماذج المحسنة كموميًا مقابل النماذج الكلاسيكية المقابلة.

- مصفوفات الارتباك (Confusion Matrices): تستخدم لتقييم أداء النماذج الهجينة مقابل النماذج الكلاسيكية.

- مخططات الدقة والخسارة (Accuracy and Loss Plots): يتم استخدام مجموعات بيانات التدريب والتحقق والاختبار لرسم الدقة والخسارة لكل دفعة، مما يوفر رؤى حول تدريب النموذج والتعميم.

تحليل النتائج:

- الانتباه الذاتي الكمومي (Quantum Self-Attention):

- حققت محاولات الرؤية الكمومية (QViT) أداءً قابلاً للمقارنة والتنافس مع محاولات الرؤية الكلاسيكية (ViT).
- لم تؤد الاختلافات في معلمة الترميز α أو الأبعاد المتوقعة لقناع الانتباه إلى تغيير كبير في سلوك QViT.

- المصفوفات أحادية الوحدة (Unimodular Matrices):

- حقق تدريب مصفوفات أحادية الوحدة ذات معاملات متغيرة عبر جميع الأسلاك في دائرة كمومية نفس دقة الشبكات العصبية الكلاسيكية ولكن بمعدل أسرع مع دالة خسارة أكثر قوة.
- استخدم أفضل نموذج كمومي أداءً مصفوفة أحادية الوحدة 16×16 مع مصفوفة وحدوية عشوائية ومعلمة قياس متعلمة.

تحليل النتائج:

- شبكات عصبية سبايكنج متكاملة وكمومية (Integrated Spiking and Quantum Neural Networks):
 - وصلت نماذج سبايكنج الهجينة الكمومية-الكلاسيكية إلى دقة أعلى بشكل أسرع من نماذج الشبكات العصبية سبايكنج النقية القابلة للمقارنة.
 - حقق أفضل نموذج هجين أداءً، TQ، أعلى دقة اختبار 8.25 مرة أسرع من النموذج الكلاسيكي القابل للمقارنة، C1.
- تدريب أسرع (Faster Training):
 - بشكل عام، أظهرت النماذج الهجينة تدريبًا وتقاربًا أسرع مقارنة بالنماذج الكلاسيكية النقية.
- ترشيح الضوضاء (Noise Filtering):
 - يبدو أن مكونات سبايكنج في النماذج الهجينة تقوم بتصفية الضوضاء عند الترجمة بين دقة التدريب والاختبار.

نقاط القوة:

- **الاستكشاف:** يستكشف الباحث مجموعة متنوعة من التقنيات الجديدة لدمج التعلم الآلي الكومومي في نماذج التعلم الآلي الأخرى.
- **التجارب:** تم تصميم وتنفيذ التجارب بشكل جيد لتقييم أداء النماذج الجديدة.
- **التحليل:** يقدم الباحث تحليلًا شاملاً للنتائج ويوضح نقاط القوة والضعف في كل نهج.

جوانب يمكن تحسينها:

- **نطاق المشاكل:** يركز البحث على مهام تصنيف بسيطة نسبياً (مثل MNIST و Two Moons). قد يكون من المفيد استكشاف أداء هذه التقنيات على مشاكل أكثر تعقيداً.
- **التحليل النظري:** يمكن تعزيز البحث بتحليل نظري أكثر تعمقاً للخصائص الرياضية للتقنيات الجديدة.
- **التحسين:** يمكن استكشاف طرق لتحسين أداء الدوائر الكومومية المستخدمة، مثل استخدام هياكل دوائر أكثر تعقيداً أو طرق ترميز مختلفة.

الفصل الرابع: الاهتمام الذاتي الكلاسيكي والكمي (Classical and Quantum Self-Attention)

- **المنهجية:** في هذا الفصل، استكشف الباحث دمج مفهوم الاهتمام الذاتي (Self-Attention) المستخدم في نماذج Transformer (والشائع في معالجة اللغة الطبيعية ورؤية الحاسوب) مع الدوائر الكمومية. قام الباحث بتصميم بنية هجينة تجمع بين طبقات كلاسيكية ودوائر كمومية. تم استخدام الدوائر الكمومية كبديل لآلية الاهتمام الذاتي التقليدية في نماذج Transformer.
- **التجارب:** تم تدريب واختبار النماذج (الكلاسيكية والكمومية الهجينة) على مجموعة بيانات MNIST (لتصنيف الأرقام المكتوبة بخط اليد).
- **المقارنة:** تمت مقارنة أداء النماذج الكمومية الهجينة مع أداء نموذج Transformer كلاسيكي مكافئ لتقييم أي تحسين في الأداء.
- **النتائج:**
 - لم تحقق النماذج الكمومية الهجينة أداءً أفضل بشكل ملحوظ من نموذج Transformer الكلاسيكي.
 - لم يؤدي تغيير قيم بعض المعلمات مثل "a" أو تغيير أبعاد الإدخال إلى تحسين أداء النماذج الكمومية الهجينة.
- **التحليل:** تشير النتائج إلى أن دمج الدوائر الكمومية في هذه البنية لم يؤدي إلى تحسين الأداء في مهمة تصنيف الأرقام. ربما يعزى ذلك إلى أن الدائرة الكمومية المستخدمة لم تكن قادرة على التقاط الأنماط المعقدة في البيانات بشكل أفضل من الآلية الكلاسيكية.

الفصل الخامس: تعلم المصفوفات أحادية الوحدة للدوائر الكمومية (Learning Unimodular Matrices for Quantum Circuits)

- **المنهجية:** في هذا الفصل، استكشف الباحث استخدام المصفوفات أحادية الوحدة (Unimodular Matrices) كطريقة لتصميم الدوائر الكمومية القابلة للتعلم. المصفوفات أحادية الوحدة لها خصائص رياضية مفيدة تجعلها مناسبة للاستخدام في الدوائر الكمومية.
- **التجارب:** تم تدريب واختبار النماذج (الكلاسيكية والكمومية الهجينة) على مجموعة بيانات "Two Moons" (لتصنيف البيانات في شكل هلالين).
- **المقارنة:** تمت مقارنة أداء النماذج الكمومية الهجينة (باستخدام المصفوفات أحادية الوحدة) مع أداء النماذج الكلاسيكية.
- **النتائج:**
 - حققت النماذج الكمومية الهجينة أداءً مكافئاً أو أفضل من النماذج الكلاسيكية، وتدرجت بسرعة أكبر.
 - استخدام مصفوفة واحدة كبيرة (16×16) كان أفضل من استخدام مصفوفات أصغر (2×2).
 - إضافة مصفوفة عشوائية وحدوية (Random Unitary Matrix) ساعد في تحسين الأداء.
- **التحليل:** تشير النتائج إلى أن استخدام المصفوفات أحادية الوحدة هو طريقة واعدة لتصميم الدوائر الكمومية القابلة للتعلم. يسمح هذا النهج بالتقاط العلاقات المعقدة في البيانات بكفاءة.

الفصل السادس: الشبكات العصبية المتكاملة المتصاعدة والكمومية (Integrated Spiking and Quantum Neural Networks)

- **المنهجية:** في هذا الفصل، استكشف الباحث دمج الشبكات العصبية المتصاعدة (Spiking Neural Networks) مع الدوائر الكمومية. تحاكي الشبكات العصبية المتصاعدة طريقة عمل الخلايا العصبية البيولوجية بشكل أقرب من الشبكات العصبية التقليدية.
- **التجارب:** تم تدريب واختبار النماذج على مهمة تصنيف صور بسيطة (الأرقام 0 و 1 من مجموعة بيانات MNIST).
- **المقارنة:** تمت مقارنة أداء النماذج الكمومية الهجينة مع أداء الشبكات العصبية المتصاعدة الكلاسيكية.
- **النتائج:**
- حققت النماذج الكمومية الهجينة أداءً أفضل من الشبكات العصبية المتصاعدة الكلاسيكية، وتدرجت بسرعة أكبر.
- **التحليل:** تشير النتائج إلى أن دمج الدوائر الكمومية مع الشبكات العصبية المتصاعدة يمكن أن يؤدي إلى تحسين الأداء والكفاءة. قد تكون الشبكات العصبية المتصاعدة قادرة على توفير تمثيل أكثر كفاءة للبيانات، مما يسمح للدوائر الكمومية بالعمل بشكل أفضل.



Thank You